doi:10.6041/j.issn.1000-1298.2026.23.007

基于改进 U－Net 与 CatBoost 的肉牛非接触式体质量估测方法研究

杨立伟[1,2]　赵旭阳[1]　尹文龙[1]　姚　冲[1]　李思成[1]　刘　刚[1,2]

（1. 中国农业大学信息与电气工程学院，北京 100083；
2. 中国农业大学智慧农业系统集成研究教育部重点实验室，北京 100083）

摘要：针对肉牛养殖中传统人工称量牛体质量效率低、易引发应激反应等问题，本文提出一种基于改进 U－Net 与 CatBoost 的肉牛非接触式体质量估测方法。该方法采用“分割-回归”两阶段框架，首先构建了一种融合空洞空间金字塔池化（ASPP）与注意力门控机制的分割网络（A^2SPP－U－Net），通过多尺度特征融合与背景抑制，可实现复杂环境下肉牛背部区域的精确提取，分割 Dice 系数达 0.978 3。其次，提出了基于分割掩膜的轮廓面积、凸包特征、宽高比及 Hu 不变矩等多维几何特征提取方法，并在此基础上构建了基于 Bagging 集成的 CatBoost 回归模型（Bagging－CatBoost），通过平滑样本扰动与增强非线性拟合能力，显著提升体质量估测的鲁棒性与精度。该方法在体质量预测任务中平均绝对误差（MAE）为 6.68 kg，决定系数（R^2）达 0.981，性能优于随机森林、XGBoost 及 LightGBM 等主流模型。在保持低成本 RGB 采集优势的同时，有效克服了姿态差异与复杂环境的干扰，为规模化肉牛养殖的体质量自动化测量提供了可靠技术方案。

关键词：肉牛；体质量估测；图像分割；A^2SPP－U－Net；几何特征提取；集成学习

中图分类号：TP391　　**文献标识码**：A　　**文章编号**：1000-1298(2026)23-0081-09　　**OSID**：

Non-contact Weight Estimation Method for Beef Cattle Based on Improved U－Net and CatBoost

Yang Liwei[1,2]　Zhao Xuyang[1]　Yin Wenlong[1]　Yao Chong[1]　Li Sicheng[1]　Liu Gang[1,2]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Smart Agriculture System Integration*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: Aiming at the problems such as low efficiency and easy occurrence of stress response in traditional manual weighing of cattle body weight in beef cattle breeding, a non-contact estimation method for beef cattle body weight was proposed based on improved U－Net and CatBoost. This method adopted a two-stage framework of “segmentation－regression”. Firstly, a segmentation network (A^2SPP－U－Net) integrating atrous spatial pyramid pooling (ASPP) and attention gating mechanism was constructed. Through multi-scale feature fusion and background suppression, the accurate extraction of the dorsal region of beef cattle in complex environments can be achieved. The Dice coefficient for segmentation reached 0.978 3. Secondly, multi-dimensional geometric feature extraction methods such as contour area, convex hull features, aspect ratio and Hu invariant moments based on segmentation masks were proposed. On this basis, a CatBoost regression model based on Bagging ensemble (Bagging－CatBoost) was constructed. By smoothing sample perturbations and enhancing nonlinear fitting capabilities, the robustness and accuracy of body weight estimation were significantly improved. The mean absolute error (MAE) of this method in the body weight prediction task was 6.68 kg, and the coefficient of determination (R^2) reached 0.981. Its performance was superior to mainstream models such as random forest, XGBoost and LightGBM. While maintaining the advantage of low-cost RGB acquisition, it

收稿日期：2026－02－05　修回日期：2026－02－09

基金项目：国家自然科学基金项目（32272930）、中国农业大学 2115 人才工程项目和中央高校基本科研业务费专项资金项目（中国农业大学 2025TC013）

作者简介：杨立伟（1981—），女，教授，博士，主要从事智慧农业研究，E-mail：yangliwei@cau.edu.cn

通信作者：刘刚（1966—），男，教授，博士，主要从事智慧农业研究，E-mail：pac@cau.edu.cn

effectively overcame the interference of posture differences and complex environments, providing a reliable technical solution for the automatic measurement of body weight in large-scale beef cattle breeding.

Key words: beef cattle; estimation of weight; image segmentation; A^2SPP - U - Net; geometric feature extraction; ensemble learning

0 引言

实时、准确地获取家畜体质量信息,是开展精细化饲喂管理、提升养殖经济效益的重要基础,也是推动我国智慧畜牧业持续发展的关键环节之一[1]。在实际生产中,目前肉牛体质量数据获取主要依赖接触式人工称量。在此过程中,人工对肉牛的固定环节不仅流程繁琐,且极易诱发肉牛应激反应,对其摄食量与生长产生不利影响[2]。

近年来,随着计算机视觉技术的不断发展,基于图像计算机视觉的家畜体质量估测方法逐渐成为研究热点[3-6]。在特征提取与体质量回归建模方向,通过轮廓回归与回归树集成[7]方法,实现了体质量预测。Rozendo 等[8]利用 3D 点云特征[9]并引入 LASSO 回归,在一定程度上提升了模型泛化性。此外,也有研究将 YOLO 检测与手机拍摄相结合[10],验证了低成本系统在实际应用中的可行性。在算法层面,为提升复杂环境下的分割精度[11-12],部分研究者引入了注意力机制及网络结构优化策略,其中,通过 SCA - ConvNet[13]通道与空间注意力强化特征提取的方法,在肉牛体质量预测任务中取得了较为理想的效果。然而,现有研究仍存在以下局限性:高精度体质量估测方法多依赖于三维扫描设备[14-17],硬件成本较高,难以在普通养殖场景中推广应用;现有分割模型[18-19]在复杂光照、遮挡及复杂背景干扰下,边缘分割精度依然有限,直接影响后续形态特征的准确性;回归模型在小样本条件下对特征噪声较为敏感,模型参数稳定性不足,预测结果的一致性难以保证。

针对上述问题,本文采集大量牛场实际复杂环境下的肉牛背部图像,构建涵盖多种站立姿态及遮挡情况的肉牛背部数据集。在此基础上,提出一种基于 A^2SPP - U - Net 与 CatBoost 回归模型的非接触式 RGB 肉牛体质量估测方法,并通过 Bagging 集成构建更准确的体质量预估策略,以期为低成本、高精度肉牛自动化体质量预估管理提供可行方案。

1 材料与方法

1.1 数据采集

本研究选取背部宽阔平直的西门塔尔肉牛为研究对象。利用牛只在饮水区自然停留的时机,在正上方 2.72 m 处部署 Orbbec Gemini 336L 型双目相机(1 280 像素 ×800 像素,30 f/s)进行长期监测,以非接触方式垂直实时采集牛背 RGB 图像,有效避免了接触式操作引发的应激。同时,同步记录耳标 ID 与电子秤称量数据,完成图像数据与体质量真值的关联,采集场景如图 1 所示。



图 1 数据采集场景图

Fig. 1 Data collection scene diagram

虽然正上方视角无法对腹围等体尺进行直接测量,但可稳定获取肉牛体高、胸宽、腹宽等数据指标,这些信息与牛体整体体型和体质量具有较强相关性。在以体质量预测为目标的应用场景下,该视角在数据稳定性和工程可部署性方面具备优势,能够为模型提供有效体型表征。

1.2 数据集构建

为增强模型泛化能力,数据采集涵盖 09:00—19:00 不同光照条件,包含抬头、扭头、颈部及尾部遮挡等自然姿态。共获取 58 头西门塔尔牛连续 10 d 的图像与体质量数据,体质量分布范围为 345 ~ 770 kg,主要集中在 550 ~ 750 kg 区间。图 2 展示了不同环境下的数据采集与标注示例。

该数据集虽然在采集时间上相对集中,但通过对同一批肉牛进行连续多日、多时段采集,引入了显著的时序变化、姿态变化及光照差异,有效提升样本多样性。采集数据的时间段覆盖图像清晰度能达标的最大范围,并包含多种真实养殖环境下的自然遮挡与姿态变化,有助于模型学习稳定的结构特征。体质量分布范围涵盖肉牛育肥的关键体质量区间,能够较好反映应用场景需求。在此基础上,使用 X - AnyLabeling 软件对图像中肉牛背部区域进行像素级标注,生成二值掩膜,构建包含 3 950 幅图像的数据集,按比例 7∶2∶1 划分为训练集、验证集与测试集。

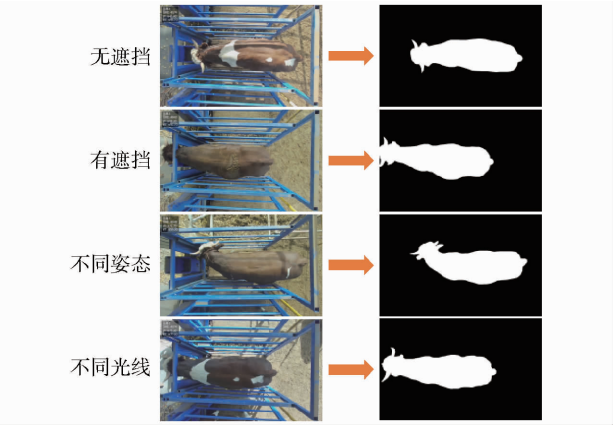

图 2　不同环境下数据采集与标注图

Fig. 2　Data collection and annotation graphs in different environments

2　网络模型设计

2.1　A^2SPP－U－Net 网络总体设计

为实现肉牛背部区域精确分割，本文在经典 U－Net 基础上，引入空洞空间金字塔池化（ASPP）与注意力门控（Attention Gate），构建 A^2SPP－U－Net（Attention＋ASPP＋U－Net）改进模型。该模型借助多尺度特征融合与空间选择性关注机制，在光照不均、遮挡、背景颜色相近等复杂畜牧场环境中，可稳定捕获肉牛背部区域，如图 3 所示。

在实际畜牧场场景中，受自然光照变化、牛体姿态差异及遮挡影响，牛背部区域往往存在亮度不一致、局部对比度下降等问题，传统卷积模型易将光照变化误判为结构边界，从而导致分割误差。针对上述问题，本文改进模型从特征尺度建模与特征选择机制两方面提升对光照变化的鲁棒性。首先，改进模型采用编码器-解码器结构，在编码器最深层嵌入 ASPP 模块，通过多尺度空洞卷积同时建模牛背部在不同姿态下的整体几何轮廓与局部纹理特征，使高层语义表示对局部形变和姿态变化具有更强的不变性。此外，多尺度上下文信息融合有助于模型在阴影区域或亮度突变区域中保持一致的目标感知能力；在解码阶段的各级跳跃连接处引入 Attention Gate，对来自浅层的空间特征进行自适应加权，能够在牛体姿态变化导致的背景暴露或遮挡区域中，有效抑制无关区域响应，突出与牛背结构一致的关键区域，从而增强不同姿态下分割结果的一致性。

在此基础上，分割结果作为后续体质量回归模型的输入，有效削弱了姿态变化对回归特征分布的影响；同时，回归阶段引入基于 Bagging 的 CatBoost 集成策略，通过对不同子样本训练得到的多模型预测结果进行平均，进一步降低由个体姿态差异引起的预测波动，从分割与回归 2 个层面协同提升整体模型对姿态差异的鲁棒性。

2.1.1　U－Net 结构

为进一步提高目标区域的分割精度，选用经典的 U－Net 网络结构[20]作为基础模型。U－Net 是典型的编码器-解码器网络，在下采样与上采样过程中，通过对称结构实现高层语义信息与低层空间细节的融合。在编码阶段，网络采用多层卷积操作并结合最大池化逐步降低特征图的空间分辨率，从而提取更加抽象的语义特征；在解码阶段，通过转置卷积逐级恢复特征图尺度，并借助跳跃连接将浅层特

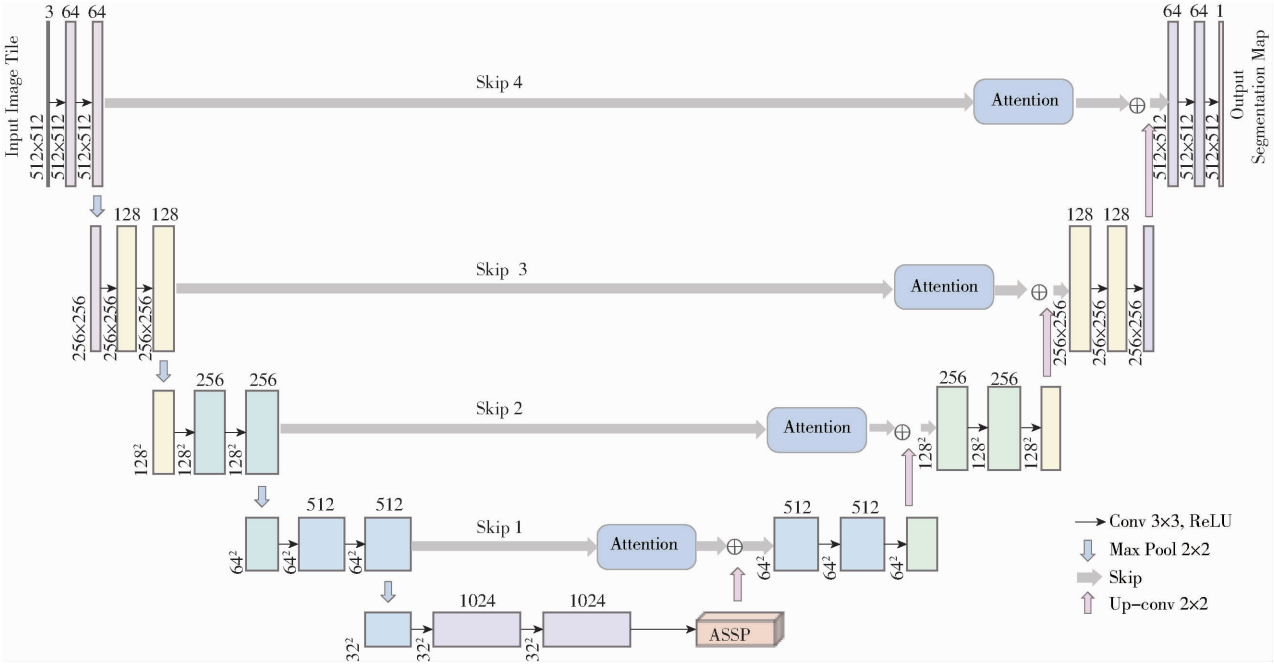

图 3　A^2SPP－U－Net 模型结构图

Fig. 3　Structural design of A^2SPP－U－Net

征引入解码路径,实现边界信息增强更精细的目标轮廓重建。本文在保持 U－Net 基本结构不变的基础上,对每一尺度上使用 2 次卷积、批归一化与 ReLU 激活的组合,以保证训练的稳定性和梯度传递效率。

2.1.2 ASPP 空洞空间金字塔池化模块

为了增强模型对不同尺度结构的感知能力,在编码器最深层加入 ASPP 模块。图 4 为 ASPP 模块结构图,其中,C_{in}、C_{out}表示输入与输出特征图的通道数,H、W 表示特征图的高度与宽度。该模块由多个具有不同空洞率的卷积并行组成,用于提取多尺度上下文。ASPP 的核心思想是通过稀疏采样扩大卷积感受野,其空洞卷积定义为

$$y[i] = \sum_{k=1}^{K} x[i + rk]w[k] \tag{1}$$

式中 $y[i]$——卷积操作输出的第 i 个特征值

$x[i + rk]$——输入特征中经空洞采样后的第 k 个邻域特征

$w[k]$——第 k 个位置对应的卷积核权重参数

K——卷积核尺寸

r——控制卷积核采样步长的空洞率,r 取 1 等价于普通卷积

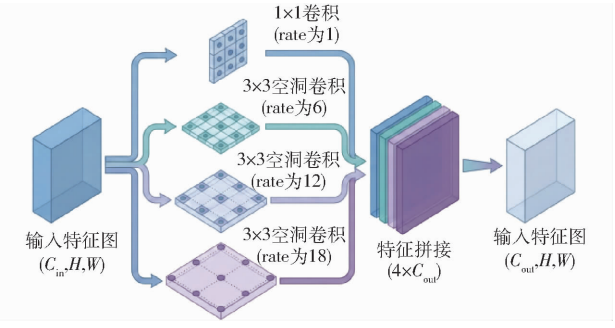

图 4 ASPP 结构示意图

Fig. 4 ASPP architecture overview

ASPP 模块中包含一条 1×1 卷积以及 3 条空洞率分别为 6、12、18 的 3×3 空洞卷积。多分支结构使得模型能够同时捕获肉牛背部的局部纹理、中尺度形状,以及大尺度的整体结构。随后,模块通过特征拼接并使用 1×1 卷积实现多尺度信息的融合,从而生成紧凑而高表达性的深层特征。

肉牛背部区域通常呈现延展且规则的几何结构,但背景复杂,易受围栏、阴影及光照不均等因素干扰。ASPP 通过多尺度并行采样与上下文信息融合,使网络更加关注稳定的结构语义特征而非局部亮度变化,从而增强对光照变化的鲁棒性,即使在光照强弱不一致或局部遮挡条件下,模型仍能稳定识别肉牛背部区域。经 ASPP 提取的深层语义特征为后续解码阶段的边缘细化与区域恢复提供了可靠基础。

2.1.3 Attention Gate 注意力机制

为提升特征融合的有效性,在 U－Net 解码阶段的所有跳跃连接中引入 Attention Gate,使解码器能够自适应选择与目标区域相关的浅层特征,并抑制无关信息。

Attention Gate 将来自解码器的深层语义特征 y 与来自编码器的浅层空间特征 x 进行线性变换后相加,再通过非线性激活与注意力映射得到空间权重。其计算过程为

$$\alpha = \sigma(\boldsymbol{\psi}^{\mathrm{T}}(\mathrm{ReLU}(W_g g + W_x x))) \tag{2}$$

其中 $\mathrm{ReLU}(z) = \max(0, z)$

式中 W_g、W_x——深层与浅层特征通道压缩的线性映射

ReLU——映射特征非线性变换函数

$\boldsymbol{\psi}$——生成单通道的注意力响应图

σ——Sigmoid 激活函数

z——经线性映射后深层特征与浅层特征的融合特征

α——空间注意力权重

2.2 Bagging－CatBoost 体质量预测

基于 A^2SPP－U－Net 自动分割得到的肉牛二值掩码图,本文构建了一套完整的形状特征提取与 Bagging－CatBoost 回归预测模型。该改进模型的整体流程如图 5 所示。



图 5 基于 A^2SPP－U－Net 与 CatBoost 的体质量估测流程图

Fig. 5 Workflow diagram of weight estimation based on A^2SPP－U－Net and CatBoost

通过最大连通区域提取、轮廓特征构建、凸包分析及 Hu 不变矩计算,本文形成了完整的肉牛几何特征向量,特征集合为

$$\boldsymbol{F}=\{A,A_{\text{hull}},S,R,\varphi_1',\cdots,\varphi_7'\} \tag{3}$$

式中　A——肉牛俯视投影的轮廓像素面积

A_{hull}——凸包面积

S——目标实心度

R——目标长宽比

2.2.1　最大连通区域选择与形状特征提取

为了确保特征能够准确表征肉牛本身，而非噪声、阴影或地面区域，本文首先对二值掩码进行连通组件分析（Connected components）。给定二值图像 I，使用

$$\{R_i\}_{i=1}^{N}=\text{ConnectedComponents}(I) \tag{4}$$

计算每个连通区域像素面积 $A_i=|R_i|$。由于肉牛在图像中的投影面积通常最显著，故选择面积最大的连通区域，即肉牛主体轮廓：$R^2=\text{argmax}A_i$，保证了特征提取的一致性，使模型在光照变化、地面杂物干扰等复杂场景下仍具有鲁棒性。

2.2.2　轮廓与凸包

在利用 A^2SPP－U－Net 获得肉牛二值掩码后，首先从掩码中提取最大连通区域以获得肉牛主体，并基于该区域的外形信息计算多项几何特征。在经过轮廓检测后，可得到肉牛真实边界点集，用于描述其外形形态与面积。为了进一步衡量肉牛轮廓的饱满程度和形状复杂度，同时计算了对应的凸包，即能够以最少顶点包围轮廓的最小凸多边形。

相较于去头颈部的肉牛图像，完整头颈的肉牛轮廓，虽因头颈自然姿态存在局部非凸区域，但头颈区域整体未形成大面积无效凹陷，因此凸包面积与真实轮廓面积的差值处于可接受范围。真实轮廓面积与凸包面积之间的关系，既能够反映肉牛边缘是否存在明显凹陷，又具备足够鲁棒性，为体质量预测提供更具区分力的形状特征。此外，为了刻画肉牛在俯视图下的长度与宽度变化，还构建了轮廓的轴对齐外接矩形，通过长宽比 R 进一步量化其整体拉伸形态。

实心度 S 与长宽比 R 计算公式为

$$S=\frac{A}{A_{\text{hull}}} \tag{5}$$

$$R=\frac{w}{h} \tag{6}$$

其中　$$A=\frac{1}{2}\left|\sum_{i=1}^{n}(x_iy_{i+1}-x_{i+1}y_i)\right| \tag{7}$$

$$A_{\text{hull}}=\text{ContourArea}(h) \tag{8}$$

式中　ContourArea（·）——轮廓面积函数

w、h——轴对齐外接矩形的宽度与高度

x_i、y_i——轮廓上第 i 个顶点坐标

x_{i+1}、y_{i+1}——轮廓上第 $i+1$ 个顶点坐标

图 6 展示了轮廓、凸包（红色多边形框）及外接矩形的空间关系（围绕牛的背部轮廓创建凸包，凸性缺陷的点对应于缺陷的开始（蓝点）、缺陷的结束（黄点）和离凸包最远的点（橙点）的坐标），从视觉上体现出这些几何特征的来源及其物理意义。上述形状特征为后续的 Bagging－CatBoost 回归模型提供了有效输入，为体质量估计建立了可靠的几何基础。

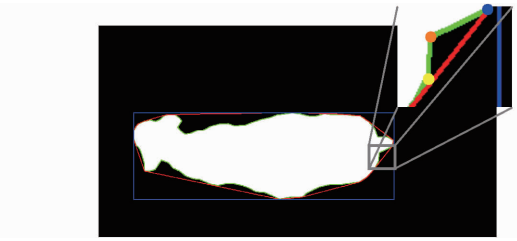

图 6　肉牛背部轮廓凸包

Fig. 6　Dorsal convex contour of beef cattle

2.2.3　Hu 不变矩特征

在完成对肉牛主体区域的分割后，进一步计算 7 个 Hu 不变矩来描述肉牛更高层次的几何结构特征。Hu 不变矩由基于二阶与三阶中心矩组合而成，具有平移不变性、旋转不变性、尺度不变性的特征，因此能够在不同拍摄角度、距离变化和姿态轻微波动的情况下保持稳定。本文按照经典公式提取 7 个 Hu 矩，构成特征向量：$\boldsymbol{\varphi}=[\varphi_1,\varphi_2,\cdots,\varphi_7]$，并采用对数变换提升数值稳定性，表达式为

$$\varphi_i'=-\text{sign}(\varphi_i)\lg(|\varphi_i|+10^{-12}) \tag{9}$$

式中　φ_i'——变换后的特征值

sign（·）——符号函数

2.2.4　Bagging 方法

在回归建模任务中，Bagging 作为基础集成策略构成了模型的第 1 层结构，其主要目的在于提升模型在有限样本和特征噪声条件下的稳定性与泛化能力。Bagging 的核心思想在于通过多次有放回随机采样构造多个训练子集，从而在模型层面对训练样本的扰动进行广义平均意义下的“方差平滑”。设原始训练集为 $D=\{(\boldsymbol{F}_i,y_i)\}_{i=1}^{n}$，Bagging 首先按照如下方式构造第 k 个子样本集，即

$$\begin{cases}D_k=\{(\boldsymbol{F}_{i_j},y_{i_j})\}_{j=1}^{n}\\ i_j\sim\text{Uniform}\{1,2,\cdots,n\}\end{cases} \tag{10}$$

独立训练对应的基学习器 $f_k(\cdot)$。最终对某一测试特征向量 $\boldsymbol{F}$ 的预测由多个子模型的输出平均得到

$$\hat{y}=\frac{1}{M}\sum_{k=1}^{M}f_k(\boldsymbol{F}) \tag{11}$$

式中　M——基学习器数量

Bagging 的预测相当于对多个独立估计器求期

望,因此能够有效降低估计方差。具体而言,该策略能够对因姿态差异引起的形状特征噪声、个体间形态变异,以及遮挡导致的局部特征不完整等误差具有良好抑制能力。相比于单一回归模型容易受到重采样扰动影响,Bagging 输出的平均预测使模型响应曲线更加平滑,从而显著提升了体质量预测任务的稳健性与可靠性。基于此,Bagging 不仅为本文整体回归框架提供了稳健基础,也为后续结合 CatBoost 的非线性建模奠定了坚实的集成结构保障。

2.2.5 Bagging + CatBoost 回归模型

在本文的体质量预测模型中,CatBoost 作为单一基学习器虽然具有对类别编码、非线性关系建模能力强、对不平衡数据敏感性低等优势,但在受限样本规模下仍可能表现出一定程度的方差波动。为了进一步提升预测结果的泛化性能,将 CatBoost 回归器与 Bagging 框架相结合,使其在保持 CatBoost 深层特征建模优势的同时,通过多模型平均机制有效降低预测方差。具体而言,Bagging 会从原始训练集随机采样多个子集,每个子集训练一个 CatBoost 基学习器 $f_m(x)$,这些 CatBoost 基学习器之间相互独立,而每个基学习器内部仍遵循 CatBoost 的梯度提升机制,即内部仍按照残差回归思想不断迭代更新整体模型输出 $F_m(x)$。在预测阶段,所有 CatBoost 子模型的输出被统一平均,从而形成稳定且对噪声不敏感的最终预测结果 $\hat{y}$。

图 7 展示了基于 Bagging 集成策略的 CatBoost 回归模型整体流程。通过对原始训练数据进行多次 Bootstrap 重采样,构建多个子训练集,并在每个子集上独立训练 CatBoost 回归模型。在预测阶段,各子模型输出结果通过均值方式进行融合,从而获得最终预测结果。

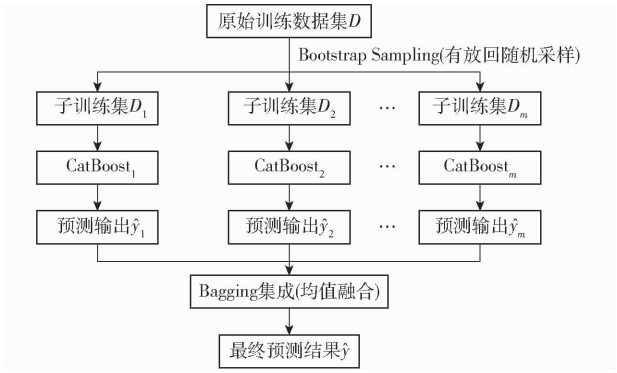

图 7 基于 Bagging 集成的 CatBoost 回归模型流程图

Fig. 7 Flowchart of the Bagging-Ensemble-based CatBoost regression model

在此组合过程中,CatBoost 内部的 boosting 机制负责学习特征空间中的复杂关系,通过逐轮拟合残差以最小化损失;而外层 Bagging 则通过对训练集的扰动加上模型输出平均,使 CatBoost 不再过度依赖于某一批次数据的统计特性,从而进一步提升稳定性和鲁棒性。由于每个 CatBoost 模型内部的函数更新均可表示为由上一次模型输出 $F_{m-1}(x)$ 加上一个步长缩放后的新弱学习器 $h_m(x)$,因此组合后仍保留了梯度提升的特征表达能力。最终,模型通过对所有成员 CatBoost 回归器的预测求平均,得到全局更平滑、更可靠估计,计算式为

$$F_m(x) = F_{m-1}(x) + \eta h_m(x) \tag{12}$$

式中 η——学习率

3 实验与结果分析

3.1 实验环境

所有实验均在统一配置的服务器上进行,以保证结果的可比性与可复现性。实验平台操作系统为 Ubuntu 20.04,硬件配备 NVIDIA RTX 4090 GPU (24 GB)及 Intel Xeon Gold 6430 CPU。软件环境方面,基于 Python 3.8 与 PyTorch 2.5.0 深度学习框架开发。模型训练的关键超参数设置如表 1 所示,A^2SPP - U - Net 分割网络训练 100 轮,采用 Adam 优化器并设置初始学习率为 0.000 1,以确保网络在低学习率下稳定收敛并有效捕捉图像中肉牛的精细结构特征;CatBoost 回归模型迭代 600 轮,学习率设为 0.05,树深度为 8,结合外层 Bagging 集成框架中的 10 个子模型通过自助重采样生成多个基学习器,实现对单一模型方差的平滑,提升预测的稳健性与鲁棒性。

表 1 参数设置

Tab. 1 Parameters setting

模型阶段	超参数	数值/类型
A^2SPP - U - Net 分割	训练轮次	100
	优化器	Adam
CatBoost 回归模型	迭代次数	600
	学习率	0.05
	Bagging 数量	10

3.2 评价指标

为全面评估模型性能,分割任务采用 Dice 系数、交并比(IoU)、精确率(Precision)、召回率(Recall)及损失值(Loss)作为评价指标。回归任务则选用平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数(R^2),分别从绝对误差、对异常值的敏感性、相对误差以及趋势拟合优度等多个维度进行量化分析。

3.3 A^2SPP - U - Net 消融实验

为验证各改进模块在模型性能提升中的具体作用,本文设计并开展了系统的消融实验,相关结果如表 2 所示。基础 U - Net 模型作为对照,为后续结构

改进提供了稳定的性能基线，其 Dice 系数达到 0.968 7，说明该模型已能够较好地区分前景与背景区域。然而，由于其编码-解码结构在特征传递过程中对空间关注区域的建模能力有限，在局部细节刻画方面仍存在一定不足，尤其是在边缘区域的表达上表现不够充分。

表 2　消融实验结果

Tab. 2　Ablation study results

模型	Dice 系数	交并比	损失值	精确率/%	召回率/%	R^2
U－Net	0.968 7	0.940 2	0.120 9	96.86	97.02	0.926 7
Attention－U－Net	0.970 2	0.943 4	0.013 3	96.98	97.21	0.929 8
ASPP－U－Net	0.972 3	0.947 0	0.010 1	97.40	97.17	0.935 5
A^2SPP－U－Net	0.978 3	0.957 7	0.009 2	97.46	98.23	0.948 3

在此基础上，引入注意力门控机制构建 Attention－U－Net 后，模型的 Dice 系数提升至 0.970 2，同时损失函数值明显下降。实验结果表明，注意力机制在跳跃连接阶段能够对关键信息进行自适应加权，有效削弱背景噪声及冗余特征的干扰，使网络在分割过程中更加聚焦于肉牛主体区域。在目标边缘及细节区域，该结构表现出更为稳定的分割效果。

进一步地，当单独引入 ASPP 模块构建 ASPP－U－Net 时，模型性能得到进一步提升，Dice 系数提高至 0.972 3，IoU 及 R^2 等指标亦呈现同步增长趋势。ASPP 模块通过多尺度空洞卷积并行提取不同感受野下的上下文信息，使模型在兼顾肉牛整体轮廓的同时，能够更好地捕捉局部细节特征。因此，在尺度变化较大、站立姿态差异明显的样本中，该模型展现出更强的适应能力与泛化性能，突出了多尺度上下文建模在复杂畜体分割任务中的重要性。

综合引入 ASPP 与注意力机制后，所提出的 A^2SPP－U－Net 模型取得了最优的整体性能。其 Dice 系数提升至 0.978 3，交并比达到 0.957 7，损失值进一步降低至 0.009 2，精确率与召回率分别达到 97.46% 和 98.23%，表明模型在有效减少误检的同时，显著提升了前景区域分割的完整性。此外，R^2 提高至 0.948 3，说明预测分割结果与真实标签之间具有更高的一致性和拟合程度。上述性能提升不仅体现在像素级分割精度上，也为后续基于分割结果的几何特征提取与体质量回归建模提供了更加可靠的输入基础。

图 8 给出了不同模型在训练过程中的评价指标变化情况。可以看出，A^2SPP－U－Net 在训练初期即表现出更快的收敛趋势，并在训练后期维持了较低的损失水平和较小的指标波动范围，进一步验证了该模型在训练稳定性与泛化能力方面的综合优势。

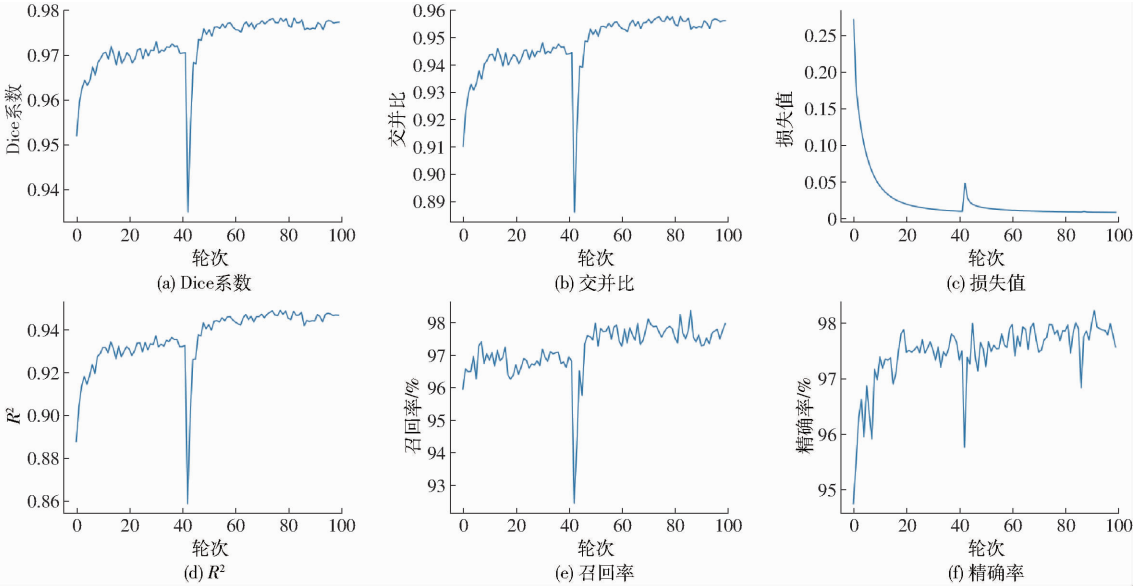

图 8　A^2SPP－U－Net 评价指标图

Fig. 8　Evaluation index charts of A^2SPP－U－Net

3.4　体质量预测结果对比分析

利用性能最优的 A^2SPP－U－Net 模型对随机选取的 300 幅测试图像进行精确分割，并在此基础上提取肉牛多维几何形状特征，随后采用多种

Bagging 集成回归模型开展体质量预测对比实验。相关实验结果如图 9 所示。分析得出，不同回归模型在相同特征输入条件下表现出明显的性能差异，表明回归策略的选择对体质量预测精度具有显著影响。

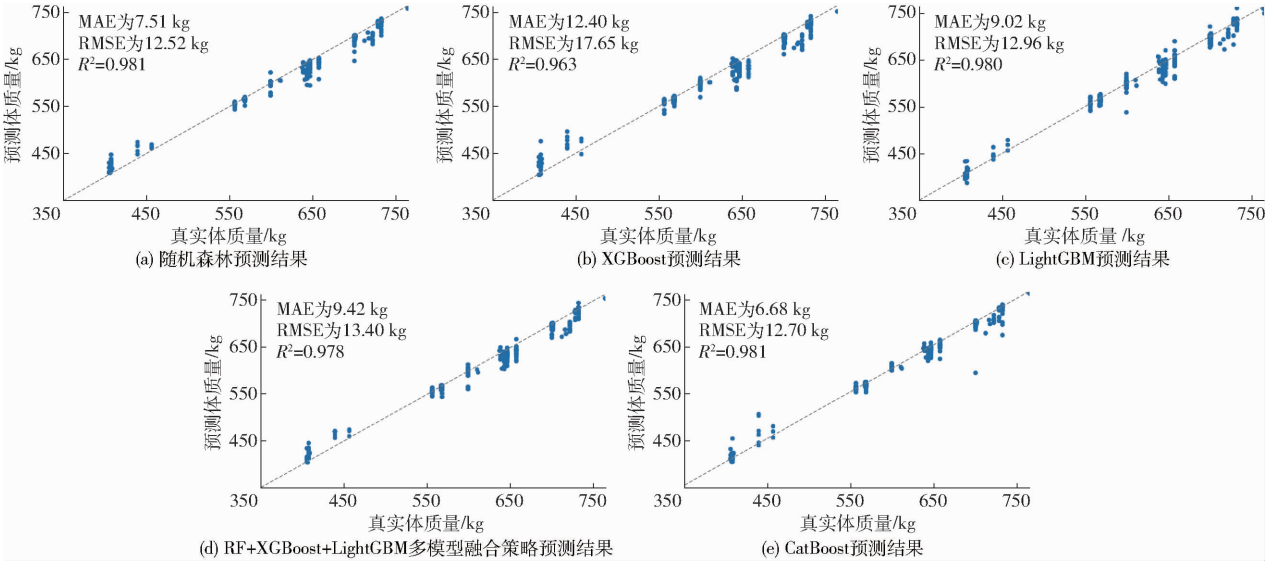

图 9 各模型体质量估测结果图

Fig. 9 Graphs of weight estimation results for each model

在所有对比方法中，本文提出的 Bagging - CatBoost 模型取得了最优的综合性能，其 MAE 为 6.68 kg，RMSE 为 12.70 kg，MAPE 仅为 1.12%，R^2 达到 0.981，说明该模型能够在真实体质量与预测值之间建立高度一致的映射关系。与 Bagging + 随机森林、Bagging + XGBoost 以及 Bagging + LightGBM 等主流集成模型相比，Bagging - CatBoost 的 MAE 分别降低了 0.83 kg、5.72 kg 和 2.34 kg，体现出其在绝对误差控制方面的显著优势。

尽管 Bagging + 随机森林的 R^2 略高，但其 MAE 与 MAPE 均明显高于 Bagging - CatBoost。这一现象表明，随机森林虽然在整体趋势拟合方面表现良好，但在样本级预测精度上仍存在一定波动，尤其对局部体质量差异的刻画能力有限。相比之下，CatBoost 通过有序提升策略与目标统计编码机制，更有效地建模了几何特征与体质量之间的非线性关系，从而在降低平均预测偏差方面表现更为稳定。

多模型融合方法（Bagging + RF + XGBoost + LightGBM）并未取得预期的性能提升，其 MAE、RMSE 与 MAPE 均高于单一的 Bagging - CatBoost 模型。这表明在当前样本规模与特征维度下，叠加回归器可能引入模型冗余与误差累积，反而削弱预测精度，而针对结构化特征高度匹配的 CatBoost 模型更有利于发挥集成学习的优势。

综上所述，实验结果充分验证了 Bagging 与 CatBoost 组合策略在该任务中的有效性：Bagging 通过对训练样本的重采样与多模型平均，有效降低了由姿态差异、分割微误差等因素引起的预测方差，而 CatBoost 则在此基础上进一步提升了对复杂非线性关系的建模能力。两者的协同作用，使得本文构建的两阶段框架能够在仅依赖低成本 RGB 图像的情况下，在复杂养殖环境中实现对肉牛体质量的高精度、稳定自动估测。

4 结论

（1）针对肉牛养殖过程中，传统人工称量牛体质量方式存在的资源消耗大、操作效率低以及易引发肉牛应激反应等问题，本文提出并验证了一种基于改进 U - Net 分割模型与 CatBoost 回归模型的非接触式体质量估测方法。研究构建了 A^2SPP - U - Net 分割网络，通过在 U - Net 框架中引入 ASPP 模块与注意力门控机制，有效增强了模型在复杂养殖环境下对肉牛背部区域的分割能力，Dice 系数达到 0.978 3，为后续几何特征的稳定提取奠定了较为可靠的结构基础。

（2）在分割结果的基础上，本文进一步设计并提取了包括轮廓面积、凸包特征、宽高比以及 Hu 不变矩在内的多维几何特征，并构建了基于 Bagging 集成策略的 CatBoost 回归模型。该模型综合利用了 Bagging 在降低模型方差方面的优势以及 CatBoost 在非线性关系建模中的表现能力，在测试集上实现了 MAE 为 6.68 kg、R^2 为 0.981 的体质量预测精度，整体性能优于多种主流集成学习方法。

（3）在仅依赖 RGB 相机的低成本硬件条件下，本文方法在一定程度上克服了光照变化、姿态差异以及局部遮挡等复杂因素的影响，实现了与依赖深

度信息的体质量估测方法相近的预测精度，体现出较好的实用性与推广潜力。相关研究结果可为规模化肉牛养殖场中自动化体质量监测与精准饲喂管理提供一种可行的技术路径。

参 考 文 献

[1] 初梦苑，刘刚，司永胜，等. 基于三维重建的奶牛体重预估方法[J]. 农业机械学报，2020，51(增刊 1)：378－384.
Chu Mengyuan, Liu Gang, Si Yongsheng, et al. Predicting method of dairy cow weight based on three-dimensional reconstruction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(S1): 378－384. (in Chinese)

[2] Hu Hao, Yu Jincheng, Yin Ling, et al. An improved PointNet + + point cloud segmentation model applied to automatic measurement method of pig body size[J]. Computers and Electronics in Agriculture, 2023, 205: 107560.

[3] 赵健，周国源，王智文，等. 基于 SGPointNet + +模型的奶牛点云分割与表型自动测定系统设计[J]. 农业机械学报，2025，56(3)：180－187.
Zhao Jian, Zhou Guoyuan, Wang Zhiwen, et al. Design of automatic determination system for point cloud segmentation and morphology of dairy cows based on SGPointNet + + model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 180－187. (in Chinese)

[4] Alexey R, Vitaly K, Konstantin D, et al. Comparative analysis of machine learning algorithms for predicting live weight of Hereford cows[J]. Computers and Electronics in Agriculture, 2022, 195: 106837.

[5] Hou Zixia, Zhang Qi, Zhang Bin, et al. CattlePartNet: an identification approach for key region of body size and its application on body measurement of beef cattle[J]. Computers and Electronics in Agriculture, 2025, 232: 110013.

[6] Guvenoglu E. Determination of the live weight of farm animals with deep learning and semantic segmentation techniques[J]. Applied Sciences, 2023, 13(12): 6944.

[7] Moraes Weber V A, De Lima Weber F, Da Silva Oliveira A, et al. Cattle weight estimation using active contour models and regression trees Bagging[J]. Computers and Electronics in Agriculture, 2020, 179: 105804.

[8] Rozendo G B, Dadi M, Franco A, et al. Cattle weight estimation using 2D side-view images and estimated depth-based 3D modeling[J]. Smart Agricultural Technology, 2025, 12: 101099.

[9] 黄霞，余松科，刘兴明，等. 基于点云的生猪体尺参数自动提取方法[J]. 农业机械学报，2025，56(8)：496－506.
Huang Xia, Yu Songke, Liu Xingming, et al. Automatic extraction of pig body size parameters based on point cloud[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 496－506. (in Chinese)

[10] Nilchuen P, Suwanasopee T, Koonawootrittriron S. Integrating deep learning and mobile imaging for assessment of automated conformational indices and weight prediction in Brahman cattle[J]. Smart Agricultural Technology, 2025, 12: 101079.

[11] 王漫，吴敏琪，胡冬，等. 基于双分支 U－Net 的遥感影像稻田分割方法[J]. 农业机械学报，2026，57(3)：306－314.
Wang Man, Wu Minqi, Hu Dong, et al. Dual-branch U－Net-based method for paddy field segmentation in remote sensing imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(3): 306－314. (in Chinese)

[12] Lee C B, Lee H S, Cho H C. Cattle weight estimation using fully and weakly supervised segmentation from 2D images[J]. Applied Sciences, 2023, 13(5): 2896.

[13] Lan Leibin, Shen Lei, Wang Huaxia, et al. Estimation of cattle weight from composite image/height/length data with spatial and channel attention convolution network (SCA－ConvNet)[J]. Signal, Image and Video Processing, 2024, 18(10): 7349－7358.

[14] Afridi H, Ullah M, Nordbø Ø, et al. Analyzing data modalities for cattle weight estimation using deep learning models[J]. Journal of Imaging, 2024, 10(3): 72.

[15] Ruchay A, Kober V, Dorofeev K, et al. Live weight prediction of cattle based on deep regression of RGB－D images[J]. Agriculture, 2022, 12(11): 1794.

[16] Ruchay A, Dorofeev K, Kalschikov V, et al. Live weight prediction of cattle using deep image regression[C]//2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor), Trento-Bolzano, 2021: 32－36.

[17] Xavier C, Le Cozler Y, Depuille L, et al. The use of 3-dimensional imaging of Holstein cows to estimate body weight and monitor the composition of body weight change throughout lactation[J]. Journal of Dairy Science, 2022, 105(5): 4508－4519.

[18] He Hengxiang, Qiao Yulong, Li Ximeng, et al. Automatic weight measurement of pigs based on 3D images and regression network[J]. Computers and Electronics in Agriculture, 2021, 187: 106299.

[19] Wang Y, Kooistra L, Mücher S, et al. Integrated unmanned aerial vehicle-based LiDAR and RGB data for individual cattle growth monitoring in precision livestock farming[J]. Sci. Data, 2025, 12: 1318.

[20] Ronneberger O, Fischer P, Brox T. U－Net: convolutional networks for biomedical image segmentation[M]. Cham: Springer International Publishing, 2015.